

Artikel ini telah dipresentasikan dalam *Innovative and Creative Information Technology Conference (ICITech)* dengan tema “*E-Transaction and Power Play*” yang diselenggarakan oleh Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana – Salatiga, pada 24 November 2016.

Peramalan Gabungan Rantai Markov dan Model Deret Waktu Pada Kasus Peramalan Kurs Nilai Mata Uang

Ronny Susetyoko

Politeknik Elektronika Negeri Surabaya

Jl. Raya ITS, Kampus PENS, Surabaya, Jawa Timur

Email : rony@pens.ac.id

Abstract

This research aims to model forecasting of dollar against rupiah by combining the Markov chains and time series models. Probability transition matrix arranged based on 459 time series data of the exchange rates for Australia Dollar (AUD) from October 20, 2014 until August 31, 2016. There are ten classifications were determined based on the exchange rates from sharply lower to sharply higher. Forecast results based on summation of forecast results with the magnitude of the change based on the state prediction probability. Evaluation of the best models are based on the value of Mean Squared Error (MSE) preliminary models. Then, the best models are based on Mean Absolute Percentage Error (MAPE) and Mean Absolute Deviation (MAD) forecast result. The result, there are three models that are considered the best: MC-SMA18, MC-DES10, and MC-DES10.S. The model chosen for this case is MC-DES10.S with MAPE = 0,352% and MAD = 35,107.

Keywords : Markov chains, time series model, the best models

1. Pendahuluan

1.1 Latar Belakang Masalah

Peramalan merupakan suatu proses pendugaan terhadap kejadian yang akan terjadi pada masa depan. Peramalan dapat juga diartikan sebagai proses yang dilakukan ketika ada kesenjangan waktu (*lag*) dari data aktual pada waktu tertentu dengan data yang ingin diketahui pada waktu yang akan datang. Peramalan diperlukan untuk mengetahui kapan atau bagaimana suatu peristiwa akan terjadi sehingga tindakan yang tepat dapat dilakukan [2]. Peramalan identik dengan analisis data deret waktu. Data deret waktu merupakan serangkaian data yang berupa nilai pengamatan yang diukur selama kurun waktu tertentu, berdasarkan interval waktu yang tetap [3]. Agar data deret waktu dapat digunakan dalam peramalan, maka data tersebut harus memenuhi beberapa asumsi penting. Diantaranya adalah adanya ketergantungan atau hubungan antara kejadian masa mendatang terhadap masa sebelumnya atau lebih dikenal dengan istilah adanya autokorelasi antara suatu variabel pada waktu tertentu dengan variabel itu sendiri pada waktu-waktu sebelumnya. Asumsi berikutnya adalah data masa depan mengikuti pola data yang terjadi di masa lalu dan hubungan/keterkaitan di masa lalu dapat ditentukan dengan pengamatan atau penelitian. Akurasi yang dihasilkan dari peramalan deret waktu, sangat ditentukan oleh seberapa jauh asumsi-asumsi di atas dipenuhi.

Berbagai metode telah dikembangkan dalam upaya mencari model ramalan yang mendekati pola aktual, utamanya dicirikan pada nilai *Mean Square Error* (MSE), *Mean Absolute Percentage Error* (MAPE) dan *Mean Absolute Deviation* (MAD). Pratiwi [4], menggunakan model campuran rantai Markov dan model deret waktu

untuk memodelkan dan memprediksi curah hujan. Namun MSE dan MAPE dari metode yang dikembangkan tersebut masih relatif besar. Demikian juga Rachmawansah [5], menggunakan metode *average-based fuzzy time series* untuk meramalkan nilai tukar mata uang yaitu USD-IDR dan EUR-USD. Hasil ramalan yang diperoleh kemudian dibandingkan dengan metode ARIMA. Metode ini mampu menentukan panjang interval efektif, sehingga mampu memberikan hasil ramalan dengan tingkat akurasi yang baik. Pada penelitian ini juga akan digunakan metode gabungan rantai Markov dan model deret waktu.

1.2 Tujuan Penelitian

Tujuan dari penelitian ini adalah mengembangkan metode peramalan dengan menggabungkan rantai Markov dengan model deret waktu.

1.3 Rumusan Masalah

Berdasarkan latar belakang masalah yang telah diuraikan di atas, dapat dirumuskan bahwa masalah dalam penelitian ini adalah apakah peramalan gabungan rantai Markov dan model deret waktu ini efektif dalam meramalkan kurs nilai mata uang (AUD). Efektifitas metode tersebut dipertimbangkan berdasarkan nilai MSE, MAPE, dan MAD.

2. Kajian Pustaka

2.1 Rantai Markov

Proses Markov adalah suatu proses stokastik dengan sifat bahwa jika keadaan saat sekarang diketahui, peluang keadaan dari proses di satu langkah ke depan hanya dipengaruhi oleh keadaan proses di saat sekarang. Artinya, keadaan proses di waktu-waktu lampau tidak mempengaruhi keadaan ke depan.

Rantai Markov mempunyai sifat kunci sebagai berikut: Proses stokastik X_t dikatakan mempunyai sifat Markovian jika: $P\{X_{t+1} = j | X_0 = k_0, X_1 = k_1, \dots, X_{t-1} = k_{t-1}, X_t = i\} = P\{X_{t+1} = j | X_t = i\}$ (1) untuk $t = 0, 1, \dots$ dan setiap urutan $i, j, k_0, k_1, \dots, k_{t-1}$. Sifat Markovian ini menyatakan bahwa peluang bersyarat dari “kejadian” mendatang dengan “kejadian” masa lampau dan state saat ini $X_t = i$ adalah independen terhadap kejadian di waktu lalu dan hanya tergantung pada saat ini (Hillier dan Lieberman, 2010).

Peluang bersyarat $P\{X_{t+1} = j | X_t = i\}$ untuk rantai Markov disebut peluang transisi (satu langkah). Jika untuk setiap i dan j , $P\{X_{t+1} = j | X_t = i\} = P\{X_1 = j | X_0 = i\}$ untuk $t = 1, 2, \dots$ (2)

maka peluang transisi (satu langkah) dikatakan stasioner. Oleh karena itu, peluang transisi stasioner menyiratkan bahwa peluang transisi tidak berubah seiring dengan waktu. Keberadaan peluang transisi stasioner (satu langkah) juga menyiratkan bahwa untuk setiap i, j dan $n = 0, 1, 2, \dots$,

$$P\{X_{t+n} = j | X_t = i\} = P\{X_n = j | X_0 = i\} \quad (3)$$

untuk semua $t = 1, 2, \dots$. Peluang bersyarat ini disebut peluang transisi n – langkah (Hillier dan Lieberman, 2010). Untuk menyederhanakan notasi, penulisan peluang transisi stasioner adalah sebagai berikut:

$$p_{ij} = P\{X_{t+1} = j | X_t = i\}, \quad (4)$$

$$p_{ij}^{(n)} = P\{X_{t+n} = j | X_t = i\} \quad (5)$$

Oleh karena itu, peluang transisi n – langkah $p_{ij}^{(n)}$ hanyalah merupakan peluang bersyarat sehingga sistem akan berada pada state j tepat setelah n langkah (satuan waktu), jika sistem tersebut bermula pada state ke i pada waktu t kapanpun. Oleh karena $p_{ij}^{(n)}$ adalah peluang bersyarat, maka peluang tersebut harus non negatif, dan oleh karena prosesnya harus membuat perubahan ke state lain maka peluang tersebut harus memenuhi sifat $p_{ij}^{(n)} \geq 0$ untuk semua i dan j , $n = 0, 1, 2, \dots$ dan $\sum_{j=0}^M p_{ij}^{(n)} = 1$, untuk semua i , $n = 0, 1, 2, \dots$

Bentuk matriks peluang transisi n – langkah dalam matriks transisi n – langkah

$$\mathbf{P}^{(n)} = \begin{bmatrix} p_{00}^{(n)} & p_{01}^{(n)} & \dots & p_{0M}^{(n)} \\ p_{10}^{(n)} & p_{11}^{(n)} & \dots & p_{1M}^{(n)} \\ \dots & \dots & \dots & \dots \\ p_{M0}^{(n)} & p_{M1}^{(n)} & \dots & p_{MM}^{(n)} \end{bmatrix} \quad (6)$$

2.2 Model Deret Waktu

Deret waktu adalah serangkaian pengamatan yang diambil berdasarkan urutan waktu antara pengamatan yang berdekatan dan saling berkorelasi. Sehingga dikatakan bahwa pada deret waktu, tiap pengamatan yang di ambil dari variabel berkorelasi dengan variabel itu sendiri pada waktu sebelumnya [3].

Suatu pengamatan Z_1, Z_2, \dots, Z_n sebagai suatu proses stokastik, maka variabel random $Z_{t1}, Z_{t2}, \dots, Z_{tn}$ dikatakan stasioner apabila:

$$F(Z_{t1}, Z_{t2}, \dots, Z_{tm}) = F(Z_{t1+k}, Z_{t2+k}, \dots, Z_{tm+k}) \quad (7)$$

Dikatakan *strictly stationary* apabila persamaan (7) terpenuhi untuk $m = 1, 2, \dots, n$. Deret waktu yang bersifat *strictly stationary*, waktu pengamatan tidak terpengaruh terhadap mean μ , variansi σ^2 dan kovariansi σ_k [3].

Ketidakstasioneran dalam deret waktu dibedakan menjadi dua, yaitu tidak stasioner dalam mean dan tidak stasioner dalam variansi. Tidak stasioner dalam mean dapat diatasi dengan melakukan *differencing* (pembedaan) dan untuk menstasionerkan variansi dilakukan transformasi [3]. Secara teknis, untuk melihat adanya ketidakstasioneran deret waktu dapat dilihat dari plot deret waktu dan plot *autocorrelation function* (ACF). Beberapa metode peramalan deret waktu yang sering digunakan, antara lain: metode pemulusan dan metode Box-Jenkins. Dalam metode pemulusan (*smoothing*) dapat dilakukan dua pendekatan yaitu metode perataan (*average*) dan metode pemulusan eksponensial (*Exponential Smoothing*).

Metode *exponential smoothing* merupakan metode peramalan yang cukup baik untuk peramalan jangka panjang dan jangka menengah [2]. Metode *Double Exponential Smoothing* (DES) digunakan untuk meramalkan data yang mempunyai pola *trend*, yang menggunakan komponen eksponensial dan komponen *trend* di setiap periode. Metode ini menggunakan dua bobot atau *smoothing* parameter (dua

parameter dari Holt), yaitu α dan β untuk memperbarui komponen di setiap periode. Persamaan DES adalah sebagai berikut:

$$\begin{aligned} L_t &= \alpha Z_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \\ F_{t+p} &= L_t + pT_t \end{aligned} \quad (8)$$

yang mana L_t adalah nilai pemulusan eksponensial, T_t adalah estimasi trend, α adalah konstanta pemulusan untuk estimasi eksponensial ($0 \leq \alpha \leq 1$), β = konstanta pemulusan untuk estimasi *trend* ($0 \leq \beta \leq 1$). F_{t+p} adalah hasil peramalan ke- p . Jika dalam deret waktu mengandung musiman, dapat menggunakan metode *Winter's Exponential Smoothing* (WES) dengan persamaan sebagai berikut:

$$\begin{aligned} L_t &= \alpha \frac{Z_t}{S_{t-L}} + (1 - \alpha)(L_{t-1} + T_{t-1}) \\ T_t &= \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \\ S_t &= \gamma \frac{Z_t}{L_t} + (1 - \gamma)S_{t-L} \\ F_{t+p} &= (L_t + pT_t)S_{t-L+p} \end{aligned} \quad (9)$$

Yang mana S_t adalah estimasi musiman, γ adalah konstanta pemulusan estimasi musiman, L adalah panjangnya musim, dan p adalah periode yang diramalkan.

Autoregressive Integrated Moving Average (ARIMA) sering juga disebut metode runtun waktu Box-Jenkins. Model ARIMA adalah model yang secara penuh mengabaikan independen variabel dalam membuat peramalan. ARIMA menggunakan nilai masa lalu dan sekarang dari variabel dependen untuk menghasilkan peramalan jangka pendek yang akurat. ARIMA cocok digunakan untuk observasi dari deret waktu (*time series*) secara statistik berhubungan satu sama lain (dependent). ARIMA hanya menggunakan satu variabel (*univariate*) deret waktu. Model ARIMA terdiri dari tiga langkah dasar, yaitu tahap identifikasi, tahap penaksiran dan pengujian, dan pemeriksaan diagnostik. Notasi ARIMA untuk menangani aspek musiman adalah ARIMA (p,d,q) (P,D,Q)^s. Sebagai ilustrasi, ambil model umum (ARIMA(1,1,1) (1,1,1)⁴ sebagai berikut:

$$(1 - \phi_1 B)(1 - \Phi_1 B^4)(1 - B)(1 - B^4)Z_t = (1 - \theta_1 B)(1 - \Theta_1 B^4)e_t \quad (10)$$

yang mana ϕ_1 merupakan parameter AR(1) tidak musiman, Φ_1 adalah parameter AR(1) musiman, $(1 - B)$ adalah *differencing* (pembedaan) tidak musiman, $(1 - B^4)$ adalah pembedaan musiman, θ_1 adalah parameter MA(1) tidak musiman, dan Θ_1 adalah parameter MA(1) musiman.

2.3 Model Peramalan Gabungan

Dalam model peramalan gabungan diawali dengan menentukan jumlah klasifikasi *state* berdasarkan distribusi diferensiasi data deret waktu. Berdasarkan klasifikasi tersebut didapatkan nilai tengah μ_k masing-masing kelas. Model peramalan gabungan mengikuti rumus:

$$Y_t = Z_t + \mu_{kt} \quad (11)$$

yang mana Z_t adalah hasil peramalan yang telah diseleksi sebagai model terbaik, μ_{kt} adalah nilai tengah pada kelas state ke- k yang memberikan peluang terbesar pada saat t .

3. Metode Penelitian


3.1 Sumber Data

Data yang digunakan dalam pemodelan peramalan adalah kurs nilai mata uang asing (dollar AUD) sebanyak 459 data. Data tersebut diperoleh dari informasi kurs Bank Indonesia mulai tanggal 20 Oktober 2014 sampai dengan 31 Agustus 2016. Sedangkan data untuk pengujian kinerja metode sebanyak 14 data kurs dollar AUD pada tanggal 01 – 21 September 2016 [6].

3.2 Metode Analisis

a. Klasifikasi *state*

Klasifikasi *state* dalam rantai Markov didasarkan pada distribusi diferensiasi data deret waktu nilai kurs sebanyak 459 data. Penentuan batas bawah kelas terendah (BBKR) berdasarkan pembulatan nilai kuartil ke-1 (Q1) yaitu -45, sedangkan batas atas kelas tertinggi (BAKT) adalah nilai negatif dari kuartil ke-1 (Q1), yaitu 45.



Gambar 1. Ringkasan Statistik Perubahan (Diferensiasi) Nilai Mata Uang

Selanjutnya jumlah kelas dalam klasifikasi *state* ditentukan dengan rumus: $(BAKT - BBKR)/10 + 2$ sehingga jumlah kelas = $(45 - (-45))/10 + 2 = 11$ kelas. Nilai 10 dipertimbangkan berdasarkan nilai peluang di masing-masing kelas. Dalam perhitungan awal, kode kelas “Tetap” (T) ditetapkan antara -5 sampai dengan 5. Namun hasil perhitungan peluang transisi dari T ke state yang lain sama dengan nol sehingga dilakukan perubahan jumlah kelas menjadi 10 kelas seperti disajikan pada Tabel 1.

Tabel 1. Klasifikasi State

No.	Interval Perubahan Kurs AUD	Kode Kelas	Keterangan Kelas	Nilai Tengah	Peluang
1	>45	L5	Lemah Sangat Tajam	45*	0.265
2	36 s/d 45	L4	Lemah Tajam	40	0.033
3	26 s/d 35	L3	Lemah Cukup	30	0.044
4	16 s/d 25	L2	Lemah Kecil	20	0.048
5	1 s/d 15	L1	Lemah Sangat Kecil	10	0.083
6	-15 s/d -1	K1	Kuat Sangat Kecil	-10	0.101
7	-25 s/d -16	K2	Kuat Kecil	-20	0.070
8	-35 s/d -26	K3	Kuat Cukup	-30	0.048
9	-45 s/d -36	K4	Kuat Tajam	-40	0.055
10	< -45	K5	Kuat Sangat Tajam	-45*	0.252

*Khusus kelas terendah (L5) dan tertinggi (K5), nilai tengah diambil dari batas bawah dan batas atas interval kelas

b. Penetapan matriks transisi peluang

Berdasarkan hasil perhitungan didapatkan matriks transisi peluang berukuran (10 x 10) sebagai berikut:

$$P = \begin{bmatrix} 0,1983 & 0,0248 & 0,0661 & 0,0992 & 0,0661 & 0,0826 & 0,0744 & 0,0496 & 0,0579 & 0,2810 \\ 0,2500 & 0,0000 & 0,1250 & 0,0000 & 0,0000 & 0,0625 & 0,1250 & 0,0625 & 0,0625 & 0,3125 \\ 0,2105 & 0,0000 & 0,0000 & 0,0526 & 0,0526 & 0,1579 & 0,1053 & 0,1053 & 0,0526 & 0,2632 \\ 0,1905 & 0,0476 & 0,0952 & 0,0000 & 0,0952 & 0,0476 & 0,1905 & 0,0476 & 0,0952 & 0,1905 \\ 0,3810 & 0,0476 & 0,0238 & 0,0238 & 0,0714 & 0,0714 & 0,0238 & 0,0714 & 0,0238 & 0,2619 \\ 0,2979 & 0,0213 & 0,0213 & 0,0638 & 0,0851 & 0,2553 & 0,0213 & 0,0000 & 0,0851 & 0,1489 \\ 0,2581 & 0,0323 & 0,0645 & 0,0000 & 0,0968 & 0,1613 & 0,0645 & 0,0323 & 0,0323 & 0,2581 \\ 0,3636 & 0,0000 & 0,0455 & 0,0000 & 0,1364 & 0,0000 & 0,0909 & 0,0455 & 0,0000 & 0,3182 \\ 0,3200 & 0,0400 & 0,0000 & 0,0000 & 0,1600 & 0,1200 & 0,0400 & 0,0000 & 0,1200 & 0,2000 \\ 0,2696 & 0,0435 & 0,0174 & 0,0348 & 0,1217 & 0,0783 & 0,0609 & 0,0609 & 0,0435 & 0,2696 \end{bmatrix}$$

c. Algoritma Metode Peramalan Gabungan

Mengacu pada persamaan (11), algoritma metode peramalan gabungan adalah sebagai berikut:

```

if ( $S_t = \text{"L5"}$ ) then  $Y_t = Z_t + 45$ ;
else if ( $S_t == \text{"L4"}$ ) then  $Y_t = Z_t + 40$ ;
else if ( $S_t == \text{"L3"}$ ) then  $Y_t = Z_t + 30$ ;
else if ( $S_t == \text{"L2"}$ ) then  $Y_t = Z_t + 20$ ;
else if ( $S_t == \text{"L1"}$ ) then  $Y_t = Z_t + 10$ ;
else if ( $S_t == \text{"K1"}$ ) then  $Y_t = Z_t - 10$ ;
else if ( $S_t == \text{"K2"}$ ) then  $Y_t = Z_t - 20$ ;
else if ( $S_t == \text{"K3"}$ ) then  $Y_t = Z_t - 30$ ;
else if ( $S_t == \text{"K4"}$ ) then  $Y_t = Z_t - 40$ ;
else then  $Y_t = Z_t - 45$ ;

```


d. Pemilihan model peramalan terbaik

Pada tahap awal, beberapa model deret waktu yang diterapkan yaitu: metode DES, metode WES, dan metode ARIMA. Model terbaik dari masing-masing metode tersebut dipilih berdasarkan nilai *MSE* terkecil. Selanjutnya, hasil peramalan beberapa metode tersebut dibandingkan dengan hasil metode peramalan gabungan berdasarkan nilai *MAPE* dan *MAD*.

4. Hasil dan Diskusi


Berdasarkan hasil pengolahan data yang mengikuti metodologi di atas, didapatkan hasil sebagai berikut:

a. Peramalan model deret waktu



Gambar 2. Data Deret Waktu Kurs AUD (jual)

Pada Gambar 2. dapat diidentifikasi bahwa data deret waktu kurs AUD tidak stasioner dalam mean dan variansi. Hal tersebut dikuatkan pada plot ACF pada Gambar 3, yang mana nilai-nilai autokorelasi turun lambat dan signifikan sampai lag ke-18. Sehingga solusi berikutnya adalah melakukan *differencing*.



Gambar 3. Plot ACF data kurs AUD

Berdasarkan data deret waktu hasil *differencing non seasonal* ternyata tidak dapat didapatkan model terbaik dari struktur ACF dan PACF nya. Sehingga dilakukan penaksiran dengan model *differencing seasonal*. Dari beberapa model ARIMA yang dicoba, ada 3 model terbaik dengan mempertimbangkan plot ACF dan PACF residual dan nilai *Mean Square Error* (MSE), yaitu ARIMA(0,1,0)(0,1,1)⁵, ARIMA(0,1,0)(0,1,1)¹⁰, ARIMA(0,1,0)(0,1,1)¹⁸. Nilai MSE dari masing-masing model berturut-turut adalah: 5009,66, 4956,638, dan 4927,268. Sehingga untuk model ARIMA dipilih ARIMA(0,1,0)(0,1,1)¹⁸.

Tabel 2. Estimasi Parameter ARIMA(0,1,0)(0,1,1)¹⁸


Final Estimates of Parameters (dengan parameter konstanta)

Type	Coef	SE Coef	T	P
SMA 18	0,9396	0,0262	35,85	0,000
Constant	0,2816	0,3607	0,78	0,435

Final Estimates of Parameters (tanpa parameter konstanta)


Type	Coef	SE Coef	T	P
SMA 18	0,9395	0,0262	35,86	0,000

Berdasarkan hasil uji parameter pada Tabel 2, parameter konstanta tidak signifikan dalam model sehingga dilakukan perbaikan model tanpa parameter konstanta. Untuk peramalan model WES, dicoba beberapa varian panjang data peramalan, yaitu $n = 10, 25, 50, 100$. Demikian juga untuk model DES, dicoba $n = 10, 25, 50, 100$. Hasil evaluasi dari beberapa model tersebut dapat dilihat pada Gambar 4.



Gambar 4. Nilai MSE Beberapa Model Deret Waktu

Pada Gambar 4 dapat dilihat bahwa model-model dengan nilai MSE terendah adalah model DES dan WES. Dari 11 model tersebut dievaluasi nilai-nilai MAPE masing-masing model.



Gambar 5. Nilai MAPE Beberapa Model Deret Waktu

Namun berdasarkan pertimbangan nilai-nilai MAPE (Gambar 5), hasil ramalan selama 14 periode ke depan yaitu tanggal 01 – 21 Septemebr 2016, dipilih 3 model terbaik yang mewakili dari setiap model deret waktu tersebut, yaitu: ARIMA(0,1,0)(0,1,1)¹⁸, WES10 dengan $\alpha = 0,2$, $\beta = 0,2$, $\gamma = 0,2$, dan DES10 dengan $\alpha = 0,595$, $\beta = 0,258$.

b. Peramalan model gabungan

Tahap berikutnya, ketiga model deret waktu yang telah terpilih dibandingkan kinerjanya dengan model peramalan gabungan antara rantai Markov dan model deret waktu. Hasilnya, nilai MAPE ramalan model gabungan rantai Markov dengan ARIMA(0,1,0)(0,1,1)¹⁸ atau MC-SMA18 naik dari 0,51% menjadi 0,63%. Ramalan model gabungan rantai Markov dengan WES10 atau MC-WES10 juga naik dari 0,84% menjadi 1,04%. Sedangkan ramalan model gabungan rantai Markov dengan DES10 atau MC-DES10 turun dari 0,54% menjadi 0,45%. Langkah berikutnya, dilakukan perbandingan ketiga model tersebut dengan model peramalan gabungan yang meramalkan sampai 14 periode ke depan secara langsung. Nilai-nilai MAPE perbandingan model-model tersebut dapat dilihat pada Tabel 3.

Tabel 3. Perbandingan nilai MAPE model gabungan ramalan 1 periode dan 14 periode


No.	Tanggal	MC-SMA18	MC-WES10	MC-DES10	MC-SMA18.S (14 periode)	MC-WES10.S (14 periode)	MC-DES10.S (14 periode)
1.	01-Sep-16	0.046%	0.826%	0.150%	0.153%	0.627%	0.150%
2.	02-Sep-16	0.563%	0.876%	0.304%	1.010%	1.323%	0.304%
3.	05-Sep-16	0.385%	0.419%	0.177%	0.833%	0.867%	0.177%
4.	06-Sep-16	0.356%	0.565%	0.204%	0.802%	1.011%	0.204%
5.	07-Sep-16	0.607%	0.475%	1.220%	0.161%	0.029%	0.328%
6.	08-Sep-16	0.128%	1.025%	0.451%	0.574%	1.471%	0.451%
7.	09-Sep-16	0.410%	0.880%	0.199%	0.858%	1.327%	0.199%
8.	13-Sep-16	0.989%	1.116%	0.362%	1.440%	1.567%	0.362%
9.	14-Sep-16	0.888%	1.318%	0.027%	1.340%	1.771%	0.580%
10.	15-Sep-16	1.867%	2.331%	1.057%	2.322%	2.786%	1.057%
11.	16-Sep-16	1.110%	2.105%	0.091%	1.563%	2.558%	0.645%
12.	19-Sep-16	0.288%	0.782%	0.817%	0.740%	1.234%	0.087%
13.	20-Sep-16	0.172%	0.310%	0.956%	0.624%	0.761%	0.053%
14.	21-Sep-16	1.008%	1.472%	0.325%	1.459%	1.923%	0.325%
MAPE		0.630%	1.036%	0.453%	0.991%	1.375%	0.352%

Dari Tabel 3 dapat dievaluasi bahwa model MC-DES10.S dengan ramalan 14 periode ke depan secara langsung merupakan model terbaik dari keenam model tersebut. Nilai-nilai MAD enam model tersebut dapat dilihat pada Tabel 4.

Tabel 4. Perbandingan nilai MAD model gabungan ramalan 1 periode dan 14 periode

No.	Tanggal	MC-SMA18	MC-WES10	MC-DES10	MC-SMA18.S (14 periode)	MC-WES10.S (14 periode)	MC-DES10.S (14 periode)
1.	01-Sep-16	4.658	83.054	15.085	15.342	63.054	15.085
2.	02-Sep-16	56.647	88.143	30.584	101.647	133.143	30.584
3.	05-Sep-16	38.789	42.203	17.802	83.789	87.203	17.802
4.	06-Sep-16	35.876	57.037	20.590	80.876	102.037	20.590
5.	07-Sep-16	61.273	47.947	123.071	16.273	2.947	33.071
6.	08-Sep-16	12.940	103.408	45.543	57.940	148.408	45.543
7.	09-Sep-16	41.221	88.443	19.974	86.221	133.443	19.974
8.	13-Sep-16	98.735	111.463	36.164	143.735	156.463	36.164
9.	14-Sep-16	88.341	131.178	2.692	133.341	176.178	57.692
10.	15-Sep-16	184.651	230.585	104.591	229.651	275.585	104.591
11.	16-Sep-16	110.092	208.772	9.009	155.092	253.772	64.009
12.	19-Sep-16	28.724	77.924	81.352	73.724	122.924	8.648
13.	20-Sep-16	17.138	30.884	95.314	62.138	75.884	5.314
14.	21-Sep-16	100.608	146.909	32.436	145.608	191.909	32.436
MAD		62.835	103.425	45.300	98.955	137.354	35.107

Berdasarkan nilai MAD pada Tabel 4, disimpulkan bahwa model terbaik dari keenam model tersebut adalah MC-DES10.S dengan nilai MAD = 35,107. Berikutnya, apabila dianalisis pola ramalan 14 periode ke depan untuk enam model tersebut dapat dilihat pada Gambar 6. Hasil ramalan pada model MC-DES10.S periode ke-3 atau mulai tanggal 05 September 2016 monoton turun, berbeda dengan hasil ramalan dari lima metode yang lain yang cenderung fluktuatif. Namun dari fakta tersebut, untuk kasus ramalan kurs nilai mata uang (AUD), model MC-DES10.S adalah terbaik didasarkan nilai-nilai MAPE dan MAD. Model terbaik kedua dan ketiga berturut-turut adalah MC-DES10 dan MC-SMA18 dengan nilai MAPE masing-masing adalah 0,453% dan 0,630% dan nilai MAD masing-masing adalah 45,3 dan 63,835.



Gambar 6. Ramalan 14 periode ke depan (01 – 21 September 2016)

5. Kesimpulan

Dari hasil analisis yang telah dilakukan dapat disimpulkan sebagai berikut:

- 1) Model terbaik untuk peramalan kurs nilai mata uang (AUD) adalah model gabungan rantai Markov dan *Double Exponential Smoothing* dengan jumlah data pemodelan $n = 10$ ($\square = 0,595$, $\square = 0,258$) dengan MAPE = 0,352% dan MAD = 35,107.
- 2) Untuk memilih model terbaik, pada tahap awal sebaiknya dipilih beberapa model deret waktu yang memiliki MSE terkecil dari model, serta MAPE dan MAD terkecil dari hasil ramalan.
- 3) Penetapan algoritma metode peramalan gabungan dapat dibandingkan dengan varian lain yang mempertimbangkan selang kepercayaan hasil ramalan dan peluang transisi.
- 4) Jumlah klasifikasi *state* sebaiknya juga perlu dibandingkan dengan beberapa alternatif jumlah klasifikasi *state* yang lain yang dipertimbangkan berdasarkan distribusi data.

6. Daftar Pustaka

- [1]. Hillier, F.S. dan Lieberman, (2014), Introduction to Operations Research, 10th Edition. ISBN:1259162982, 0073523453. 10 Agustus 2016.
- [2]. <http://ebooksload.com/programming-development/>
- [3]. S. Makridakis, SC Wheelwright, RJ Hyndman, (2008), Forecasting methods and applications. John Wiley & Sons.
- [4]. Wei, W. W. S., (1990), Time Series Analysis: Univariate and Multivariate Methodes. Addison-Wesley Publishing Company, Inc, New York.
- [5]. Pratiwi, Reta Yulia, Pemodelan Curah Hujan Dengan Campuran Rantai Markov Dan Model Deret Waktu, Jurusan Matematika, F.MIPA, Universitas Brawijaya. 8 Agustus 2016.
- [6]. <http://statistik.studentjournal.ub.ac.id/>
- [7]. Rachmawansah, Komet, Average-Based Fuzzy Time Series Untuk Peramalan Kurs Valuta Asing (Studi Kasus Pada Nilai Tukar USD-IDR dan EUR-USD), Jurusan Matematika, F.MIPA, Universitas Brawijaya. 10 Agustus 2016 <http://download.portalgaruda.org/>
- [8]. Informasi Kurs: Kurs Transaksi Bank Indonesia. 22 September 2016. <http://www.bi.go.id/id/moneter/informasi-kurs/transaksi-bi/>